

Marko Jerončić*
Zdravka Aljinović**

UDK 658.152(497.5)
JEL Classification G110
Stručni članak

FORMIRANJE OPTIMALNOG PORTFELJA POMOĆU MARKOWITZEVOG MODELA UZ SEKTORSKU PODJELU KOMPANIJA

U radu se primjenjuje Markowitzev (mean – variance, MV) model u formiranju optimalnog portfelja na osnovi uzorka dionica koje kotiraju na Zagrebačkoj burzi, uz ispunjavanje definiranih i postavljenih ograničenja, pri čemu se posebna pozornost pridaje sektorskoj pripadnosti kompanija, odnosno diverzifikaciji portfelja ne samo dionički nego i sektorski. Nadalje, vrlo važan aspekt pri formiranju portfelja bila je i analiza financijskih pokazatelja, koja je pokazala da neke dionice iako imaju pozitivan očekivani prinos, također imaju vrlo loše financijske rezultate i kao takve su nepoželjne u portfeljima investitora koji nisu skloni riziku i špekuliranju. Svi izračuni su predstavljeni, a provode se pomoću tabličnog kalkulatora Excel, posebno za rješavanje problema matematičkog programiranja odnosno optimizacije koristi se Excelov Rješavač (Solver). Rezultat takve sveobuhvatne analize i optimizacijskog postupka je portfelj koji spada u skupinu konzervativnih i stabilnih portfelja, jer ostvaruje vrlo solidan godišnji prinos od 12% uz relativno nisku stopu rizika. Sadrži dionice koje se smatraju blue chip dionicama na hrvatskom tržištu kapitala i ima dobru sektorsku i dioničku diverzifikaciju. Pogodan je za sve investitore koji nisu skloni riziku, ali ipak žele ostvariti solidne prinose na godišnjoj razini.

Ključne riječi: Markowitzev model optimizacije portfelja, Zagrebačka burza, sektorska podjela, analiza financijskih izvješća, Excel

* M. Jerončić, mag. oec. (e-mail: marko.jeroncic@yahoo.com).

** Z. Aljinović, redovita profesorica (e-mail: zdravka.aljinovic@efst.hr), oboje sa Ekonomskog fakulteta u Splitu.

Prva verzija članka primljena je 21. 09. 2011., a definitivna 20. 10. 2011.

1. Uvod

Upravljanje portfeljima vrijednosnica jedno je od osnovnih područja modernih korporativnih financija i jedan je od glavnih zadataka financijskih stručnjaka diljem svijeta. Od banaka i osiguravateljskih kuća, preko mirovinskih i investicijskih fondova, do proizvodnih i trgovačkih poduzeća, kao i individualnih investitora i država, svi subjekti na financijskim tržištima se u nekom trenutku susretnu sa viškom sredstava koja žele na neki način uložiti i oploditi.

Bez obzira želimo li uložiti u rizične dionice i derivative, ili želimo vrlo siguran portfelj državnih obveznica i štednih depozita, Moderna teorija portfelja (Modern Portfolio Theory - MPT) sa svojim glavnim reprezentantom – Markowitzevim modelom optimizacije portfelja, ima isti princip primjene – pronaći optimalnu kombinaciju rizika i prinosa.

U radu se pokazuje kako formirati optimalan portfelj na temelju uzorka dionica koje kotiraju na Zagrebačkoj burzi, uz ispunjavanje definiranih i postavljenih ograničenja, pri čemu se posebna pozornost pridaje sektorskoj pripadnosti kompanija, odnosno diverzifikaciji portfelja ne samo dionički nego i sektorski. Svi izračuni provode se pomoću tabličnog kalkulatora Excel, a posebno se za rješavanje problema matematičkog programiranja odnosno optimizacije koristi Excelov Rješavač (Solver).

Nakon kratkoga prikaza Markowitzevog modela, cjelokupan proces optimizacije provodi se kroz 5 faza. Prva faza je formiranje uzorka i sektorska podjela kompanija po kriteriju osnovne djelatnosti i strukture prihoda. Druga faza je prikupljanje podataka iz financijskih izvješća kompanija (objavljenih na Zagrebačkoj burzi) kako bi se stvorila baza podataka i izračunali financijski pokazatelji. Na osnovu njih će dio najlošijih kompanija iz početnog uzorka biti eliminiran i one neće biti uključene u uzorak za formiranje optimalnog portfelja. Treća faza je prikupljanje podataka za izračun tjednih cijena na osnovu kojih će se izračunati tjedne promjene cijena za promatrano razdoblje. Koriste se povijesni podatci objavljeni na Zagrebačkoj burzi. Četvrta faza je izračun osnovnih varijabli za formiranje optimalnog portfelja, koje se računaju na osnovu tjednih promjena cijena, a to su: očekivani prinosi, varijance i standardne devijacije svih dionica u konačnom uzorku, te matrica varijanci i kovarijanci. U petoj se fazi na temelju prikupljenih podataka i izračuna formira optimalni portfelj, odnosno uz pomoć Excelovog alata Solver izračunavaju udjeli dionica koje će biti uključene u portfelj s pripadajućim prinosom i standardnom devijacijom, te se prikazuju i tumače rezultati.

Rad je strukturiran na isti način. Ima dvije glavne tematske cjeline. U prvoj se prezentiraju i objašnjavaju teoretski aspekti Markowitzevog modela, a druga cjelina dokumentira empirijsku primjenu tog modela, tj. detaljno objašnjava proces formiranja optimalnog portfelja s obzirom na postavljena višestruka ograničenja.

2. Elementi Markowitzeve teorije portfelja

Osnove moderne teorije portfelja je postavio američki nobelovac Harry M. Markowitz još 1952. godine. U svojoj knjizi „Portfolio selection: Efficient Diversification of Investments“ iz 1959. razvio je teoriju prema kojoj se rizik i nagrada (prinos) mogu uravnotežiti u dobro odabranoj kombinaciji vrijednosnica – portfelju.

Osnovna Markowitzeva ideja bila je naći ravnotežu između rizika (mjerenog varijancom) i prinosa što danas nazivamo Model prosjek-varijanca (*Mean-variance model*, MV model). Tim modelom možemo, uz pretpostavku da imamo sve potrebne informacije, formirati portfelj koji na određenom stupnju rizika donosi najveću stopu prinosa, odnosno portfelj koji za zadanu stopu prinosa ima minimalni rizik.


Osnovne pretpostavke Markowitzevog modela:

- prinosi na dionice su distribuirani po normalnoj distribuciji,
- investitori žele maksimizirati svoju ekonomsku korisnost,
- investitori su racionalni i imaju averziju prema riziku,
- investitori su dobro obaviješteni o svim relevantnim činjenicama potrebnima za donošenje investicijske odluke,
- nema transakcijskih i poreznih troškova,
- vrijednosnice su savršeno djeljive.

Također je pretpostavljeno da investor ima slobodan izbor od N rizičnih vrijednosnica s poznatim očekivanim prinosom, varijancom i standardnom devijacijom, kao i matricom njihovih varijanci i kovarijanci. Skup mogućih portfelja čine svi portfelji koji se mogu sastaviti od N zadanih rizičnih vrijednosnica. Svaki portfelj karakteriziran je svojim (očekivanim) prinosom i svojim rizikom (varijancom prinosa ili standardnom devijacijom) i možemo ga prikazati točkom u koordinatnom sustavu tako da dobijemo skup kao na slici 1.

Slika 1.

SKUP MOGUĆIH PORTFELJA



Izvor: Aljinović, Marasović, Šego, (2011), str. 139.

Lijeva granica skupa mogućih portfelja se naziva *skup minimalne varijance* (*minimum-variance set*). Njea sačinjavaju točke koje za danu stopu prinosa imaju najmanju varijancu. Dio skupa minimalne varijance koji prikazuje portfelje koji za zadanu standardnu devijaciju imaju maksimalan prinos naziva se *efikasnom granicom* (*efficient frontier*), a portfelji koji leže na efikasnoj granici *efikasni portfelji*. Upravo je pronalaženje efikasnih portfelja zadatak ovog modela.

Matematički, efikasni portfelj možemo definirati kao rješenje sljedećeg problema:

$$\max E(R_\pi) = \pi' \cdot E(R) = \sum_{i=1}^N \pi_i \cdot E(R_i), \quad (1)$$

uz ograničenja:

$$\pi' S \pi = c \quad (2)$$

$$\sum_{i=1}^N \pi_i = 1, \quad (3)$$

$$\pi_i \geq 0, \quad (4)$$

pri čemu je π vektor udjela π_i vrijednosnica u portfelju, $i = 1, \dots, n$ (π' je transponirani vektor udjela), $E(R)$ vektor očekivanih prinosa vrijednosnica $E(R_i)$, S matrica varijanci i kovarijanci, c je konstanta koja prikazuje rizik mjeren varijancom koji je investitor spreman prihvatiti, vrijedi naime da je $\pi' S \pi = \sigma_\pi^2$ - varijanca portfelja. Uočimo, uvjet (4) o nenegativnosti udjela kaže zapravo da kratka prodaja nije dozvoljena.

Nepoznate varijable u ovom modelu su udjeli pojedinih dionica u portfelju π_i . Zbog toga je u praksi potrebno koristiti programske pakete koji su u mogućnosti iterativnom metodom mijenjati i kombinirati udjele dionica (ili bilo kojih drugih vrijednosnica) kako bi postigli optimalnu kombinaciju, tj. efikasni portfelj.

Iako je Harry M. Markowitz za model 1990. godine dobio i Nobelovu nagradu, model nije prošao bez kritika znanstvene i financijske zajednice. Jedna je od glavnih kritika pretpostavka da su prinosi normalno distribuirani. Naime, prinosi su rezultat cijena koje se formiraju tržišnim snagama koje nisu nasumične, nego se zasnivaju na ekonomskim zakonitostima, te očekivanjima i procjenama investitora. Distribucije prinosa najviše odudaraju od normalne distribucije za vrijeme izrazitog gospodarskog uzleta ili gospodarske krize – onda kada je ispravnost pretpostavki najvažnija.

Ostale kritike uključuju pretpostavke racionalnosti investitora i njihove nesklonosti riziku, koje u nekim slučajevima nisu točne, te pretpostavku dobre informiranosti svih investitora za koju je poznato da zbog asimetrije informacija i agencijskog problema nije u potpunosti točna. Transakcijski troškovi i utjecaj poreza, kao i nemogućnost savršenog usitnjavanja vrijednosnica, također predstavljaju prepreke ovom modelu.

Unatoč ovim kritikama Markowitzeva teorija portfelja predstavlja najznačajniju inovaciju u 20. stoljeću na području upravljanja portfeljima. Ona je omogućila da se dotadašnja financijska i fundamentalna analiza, koje su bile temeljene na računovodstvenim metodama, nadopune sa vrlo moćnim statističkim oruđem, koje u kombinaciji nudi još bolje rezultate i uključuje u analizu kvantificiranu varijablu rizika. Iako u ekstremnim tržišnim uvjetima ponešto neprecizna, u normalnim tržišnim uvjetima, na razvijenim i likvidnim tržištima kapitala, pokazala se kao nezamjenjiv alat u modernom upravljanju portfeljima.

3. Formiranje optimalnog portfelja

3.1. Uzorak promatranih dionica

Likvidnost dionice je glavni kriterij pri formiranju početnog uzorka dionica. Likvidnost je bitna za aktivno upravljanje portfeljem jer omogućava da u svakom trenutku kupimo ili prodamo dionicu bez značajnijeg porasta odnosno pada cijene. Likvidnih dionica također ima na burzi i u većim količinama, što je bitno ako se radi o visokim iznosima kojima upravljamo u portfelju jer smo onda u mogućnosti kupiti ili prodati relativno veću željenu količinu. Likvidnost dionice bi također u pravilu trebala osigurati i fer vrednovanje same dionice, jer veliki broj transakcija, barem u teoriji, osigurava konvergenciju cijene dionice ka ravnotežnoj cijeni ponude i potražnje, koje su pak uvjetovane tržišnim silama i očekivanjima investitora.

Sukladno tome početni uzorak dionica se sastoji od 25 sastavnica koje su činile burzovni indeks CROBEX Zagrebačke burze na dan 21. ožujka 2011. i 17 dionica s najvećim prometom u 2010. godini koje nisu sastavnice indeksa CROBEX. U tablici 1 nalaze se dionice uvrštene u početni uzorak.

Dionice koje su sastavnice CROBEX-a automatski zadovoljavaju kriterij likvidnosti koji je postavljen za uključivanje u uzorak, kao i kriterije broja dana trgovanja i određene *free float* kapitalizacije, s obzirom da su to uvjeti za i uključivanje u CROBEX. Ostalih 17 dionica su uključene izravno po kriteriju likvidnosti koja je definirana kroz ukupan promet trgovine ostvaren u 2010. godini.

Tablica 1:

DIONICE UVRŠTENE U POČETNI UZORAK ZA FORMIRANJE PORTFELJA

R.br.	Simbol	Izdavatelj	R.br.	Simbol	Izdavatelj
1	ADPL-R-A	AD Plastik d.d.	1	CROS-R-A	Croatia osiguranje d.d.
2	ADRS-P-A	Adris grupa d.d.	2	DDJH-R-A	Đuro Đaković Holding d.d.
3	ATGR-R-A	Atlantic Grupa d.d.	3	DIOK-R-A	Dioki d.d.
4	ATPL-R-A	Atlantska plovidba d.d.	4	FRNK-R-A	Franck prehrambena ind. d.d.
5	BLJE-R-A	Belje d.d. Darda	5	HDEL-R-A	Hidroelektra niskogradnja d.d.
6	CKML-R-A	Čakovečki mlinovi d.d.	6	ISTT-R-A	Istraturist Umag d.d.
7	DLKV-R-A	Dalekovod d.d.	7	JDPL-R-A	Jadroplov d.d.

R.br.	Simbol	Izdavatelj	R.br.	Simbol	Izdavatelj
8	ERNT-R-A	Ericsson Nikola Tesla d.d.	8	JNAF-R-A	Jadranski naftovod d.d.
9	HT-R-A	HT d.d.	9	KSST-R-A	Kaštelanski staklenici d.d.
10	IGH-R-A	Institut IGH d.d.	10	LKRI-R-A	Luka Rijeka d.d.
11	INA-R-A	INA d.d.	11	LRH-R-A	Liburnija riviera hoteli d.d.
12	INGR-R-A	Ingra d.d.	12	MAIS-R-A	Maistra d.d.
13	KNZM-R-A	Konzum d.d.	13	RIVP-R-A	Riviera Poreč d.d.
14	KOEI-R-A	Končar-elektroindustrija d.d.	14	TISK-R-A	Tisak d.d.
15	KORF-R-A	Dom Holding d.d.	15	TNPL-R-A	Tankerska plovdba d.d.
16	KRAS-R-A	Kraš d.d.	16	VDKT-R-A	Viadukt d.d.
17	LEDO-R-A	Ledo d.d.	17	VLDS-R-A	Validus d.d.
18	LKPC-R-A	Luka Ploče d.d.			
19	PBZ-R-A	PBZ d.d.			
20	PODR-R-A	Podravka d.d.			
21	PTKM-R-A	Petrokemija d.d.			
22	THNK-R-A	Tehnika d.d.			
23	ULPL-R-A	Uljanik Plovidba d.d.			
24	VIRO-R-A	Viro tvornica šećera d.d.			
25	ZABA-R-A	Zagrebačka banka d.d.			

3.2. Sektorska podjela kompanija

Jedan od ciljeva ovog rada je pokazati kako uključiti sektorsku pripadnost kompanija u formiranju uzorka, te istražiti moguće implikacije te pripadnosti na formiranje optimalnog portfelja.

Kompanije dijelimo po sektorima ovisno o tome koja je njihova glavna djelatnost. Međutim, često se događa da kompanije u svoje statute uključe jako veliki broj različitih djelatnosti kako bi bile što fleksibilnije u svom poslovanju, tim više što svaka promjena djelatnosti iziskuje odobrenje skupštine dioničkog društva, te promjenu statuta, što je svakako dugotrajan, a ponekad i skup proces. Stoga kompanije preventivno uključuju mnoge djelatnosti u svoje statute, čak iako znaju da se neće tako skoro tim djelatnostima baviti. Zbog toga je ponekad teško jasno razlučiti osnovnu djelatnost s obzirom da u statutima postoji jako veliki broj navedenih djelatnosti kompanija. U načelu, ako postoji dvojba, kompanija se svrstava u onaj sektor u kojem ostvaruje najveći prihod od prodaje, odnosno najveći prihod od poslovanja općenito. Tim načelom se vodilo pri klasifikaciji kompanija iz početnog uzorka.

Državni zavod za statistiku provodi svoju sektorsku klasifikaciju¹, međutim ona je sklona vrlo detaljnim podjelama na podsektore i nije prikladna za primjenu kod relativno malih uzoraka kao što je naš od 42 kompanije. Osim toga, ta je podjela osmišljena prvenstveno za statističke svrhe i zbog toga zanemaruje neka načela koja se koriste za klasifikaciju u financijskoj industriji.

Sektorska podjela je u ovom slučaju obavljena prema „Global Industry Classification Standard“-u (GICS)² koji su razvili investicijska kompanija Morgan Stanley Capital International i bonitetna kuća Standard & Poor's i kojim se koriste na razvijenim tržištima kapitala. Taj standard dijeli kompanije po glavnim djelatnostima na 10 sektora, 24 industrijske grupe, 68 industrija i 154 pod-industrije.

Za formiranje osnovnih kategorija koristilo se kombinacijom GICS-ovih sektora i industrijskih grupa. Takva podjela je bila nužna s obzirom da Republika Hrvatska nema razvijene sektore informatičkih tehnologija, farmacije i biotehnologije, te materijala (osim papira i cementa), dok su neke industrijske grupe (niža hijerarhijska razina) od strateške važnosti i praktično na razini najviših sektora, primjerice turizam i hotelijerstvo, poljoprivreda, i brodski transport. Kao dodatni sektor uvedena je i kategorija „Diverzificirano“ gdje se nalaze holding kompanije koje imaju značajne i ravnopravne prihode iz više različitih sektora, te ih je teško svrstati u jedan od standardnih sektora. Primjeri takvih kompanija su Adris grupa d.d. koja se bavi turizmom, duhanskom i prehrambenom industrijom, te Validus d.d. koji se bavi turizmom, financijskim uslugama i prehrambenom industrijom.

Sukladno tome imamo 10 osnovnih sektora po kojima dijelimo 42 kompanije iz početnog uzorka: Diverzificirano, Energetika, Financijske usluge, Građevina, Hotelijerstvo i turizam, Industrija, Poljoprivreda, Prehrana i maloprodaja, Telekomunikacije, Transport.

Kompanije iz početnog uzorka su razvrstane po sektorima, a podjela je prikazana u Tablici 2.

Nakon analize financijskih izvješća i izračuna pokazatelja, ovaj će početni uzorak biti smanjen za određeni broj dionica s najlošijim pokazateljima. Sektorska podjela neće imati utjecaja pri analizi izvješća, ali će imati utjecaj na formiranje optimalnog portfelja. Naime ograničenja neće biti postavljena samo na razini pojedine dionice, nego i na razini cijelih sektora. Cilj je formirati sektorski diverzificiran i uravnotežen portfelj sa optimalnom kombinacijom prinosa i rizika.

¹ Nacionalna klasifikacija djelatnosti 2007. (NN 58/07 i 72/07)

² <http://www.mscibarra.com/products/indices/gics/>

Tablica 2:

SEKTORSKA PODJELA DIONICA IZ POČETNOG UZORKA

Sektor	Dionica	Sektor	Dionica
Diverzificirano (3)	ADRS-P-A	Industrija (nastavak)	KOEI-R-A
	KORF-R-A		PTKM-R-A
	VLDS-R-A	Poljoprivreda (4)	BLJE-R-A
Energetika (2)	INA-R-A		CKML-R-A
	JNAF-R-A		KSST-R-A
Financijske usluge (3)	CROS-R-A		VIRO-R-A
	PBZ-R-A	Prehrana i maloprodaja (7)	ATGR-R-A
	ZABA-R-A		FRNK-R-A
Građevina (6)	DLKV-R-A		KNZM-R-A
	HDEL-R-A		KRAS-R-A
	IGH-R-A		LEDO-R-A
	INGR-R-A		PODR-R-A
	THNK-R-A		TISK-R-A
	VDKT-R-A	Telekomunikacije (2)	ERNT-R-A
Hoteljerstvo i turizam (4)	ISTT-R-A		HT-R-A
	LRH-R-A	Transport (6)	ATPL-R-A
	MAIS-R-A		JDPL-R-A
	RIVP-R-A		LKPC-R-A
Industrija (5)	ADPL-R-A		LKRI-R-A
	DDJH-R-A		TNPL-R-A
	DIOK-R-A		ULPL-R-A

3.3. Analiza financijskih izvješća

Da bi formirali optimalni portfelj, u teoriji je dovoljno imati povijesna kretanja cijena dionica u uzorku za promatrano razdoblje. Na osnovi njih se mogu izračunati dnevne, tjedne ili mjesečne promjene koje su osnova za sve izračune u Markowitzevom modelu. Međutim, analiza financijskih izvješća kompanija u uzorku nam omogućava da odmah u početku eliminiramo „nepoželjne“ dionice iz razmatranja i tako suzimo uzorak za primjenu Markowitzeva modela.

Analiza financijskih izvješća uključuje analizu trendova kretanja financijskih kategorija, kao i izračun financijskih pokazatelja. Najčešće se računaju četiri

osnovne skupine pokazatelja: pokazatelji profitabilnosti, pokazatelji obrtaja imovine, pokazatelji likvidnosti i solventnosti, te pokazatelji efikasnosti investiranja dioničara.

S obzirom da je u središtu interesa ovog rada formiranje optimalnog portfelja koristeći Markowitzev model, a ne dubinska financijska analiza, ograničili smo se na izračun osnovnih financijskih pokazatelja za sve kompanije iz uzorka za 2010. godinu.

Pokazatelji profitabilnosti su Prinos na kapital (ROE), Prinos na aktivu (ROA), te Zarada po dionici (EPS). Ovi pokazatelji omogućavaju univerzalnu usporedbu profitabilnosti i efikasnosti kompanija kako između tako i unutar pojedinih sektora. Dodatni pokazatelj je Indeks financijske poluge koji pokazuje koliko dobro kompanija koristi financijsku polugu, odnosno u kojoj joj je mjeri poluga prijetnja ako ostvaruje negativan financijski rezultat. Kod sva tri pokazatelja poželjna je što veća vrijednost, osim kod Indeksa financijske poluge ako kompanija ima negativan financijski rezultat. U tom slučaju viši pokazatelj znači da financijska poluga brže umanjuje kapital kompanije.

Pokazatelji obrtaja imovine su Koeficijent obrtaja dugotrajne imovine i Koeficijent obrtaja kratkotrajne imovine. Veći koeficijent znači i veći obrtaj i utoliko je kompanija efikasnija. Ovi pokazatelji mogu značajno varirati između različitih sektora, stoga su bolji za usporedbu kompanija unutar sektora. U pravilu je za ove pokazatelje bolje što su oni viši.

Pokazatelji likvidnosti i solventnosti pokazuju „zdravlje“ kompanija, odnosno njihovu sposobnost da podmiruju dugotrajne i kratkotrajne obveze. U ovoj skupini imamo Koeficijent opće likvidnosti, Koeficijent ubrzane likvidnosti, i Koeficijent zaduženosti. Koeficijent opće likvidnosti pokazuje sposobnost poduzeća da pokrije svoje kratkoročne obveze kratkotrajnom imovinom i u pravilu bi trebao iznositi barem 2. Koeficijent ubrzane likvidnosti se računa na isti način, osim što se kratkotrajna imovina umanjuje za zalihe. Ovaj pokazatelj treba iznositi barem 1, a služi da bi pokazao stanje likvidnosti ukoliko bi došlo do velikog pada prodaje. Koeficijent zaduženosti pokazuje udio obveza, odnosno duga u ukupnoj imovini. Koeficijent veći od 0,5 pokazuje da se kompanija u većoj mjeri financira iz duga nego iz vlastitoga kapitala i da kapital ne može pokriti sve obveze, te je bitan pokazatelj za kreditore i dioničare.

Pokazatelji efikasnosti investiranja dioničara stavljaju u vezu financijski rezultat poduzeća u odnosu na trenutačnu tržišnu cijenu na burzi, uzevši u obzir razlike u broju emitiranih dionica od poduzeća do poduzeća. Iako postoje sektorski vezane specifičnosti ovih pokazatelja, spomenuta relativizacija financijskog rezultata omogućuje usporedbu kompanija i između i unutar različitih industrija. U ove pokazatelje spadaju prije spomenuta Zarada po dionici (EPS), odnos tržišne cijene i zarade po dionici (P/E ratio), knjigovodstvena vrijednost po dio-

nici (BVPS), te odnos tržišne cijene i knjigovodstvene vrijednosti po dionici (P/BVPS). P/E ratio ima okvirne vrijednosti po industrijama, međutim one se uglavnom zasnivaju na empirijskim podacima s američkih tržišta kapitala i stoga je njihova upotreba za uspoređivanje hrvatskih kompanija upitna. Opće pravilo je da relativno niži pokazatelj znači podcijenjenu, a relativno viši pokazatelj precijenjenu dionicu. Međutim, valja uzeti u obzir da tržišta nisu savršena i da investitori mogu pogriješiti. Relativno niži pokazatelj može značiti i da kompanija ima određenih problema, te da iako ima relativno dobre rezultate, investitori su „ugradili“ rizik u trenutnu cijenu i zbog toga je dionica podcijenjena. S druge strane relativno viši pokazatelj može značiti da iako kompanija ima relativno loše rezultate sada, postoje optimistična očekivanja za budućnost i ona su ugrađena u relativno visoku cijenu dionice. S obzirom da se i pokazatelj P/BVPS zasniva na trenutnoj tržišnoj cijeni dionice, i za njega vrijede isti principi. Relativno nizak pokazatelj može značiti priliku za kupovinu podcijenjene dionice, ali i već ugrađena negativna očekivanja o budućim teškoćama u poslovanju. Relativno visok pokazatelj može značiti precijenjenu kompaniju, ali i kompaniju koja će biti puno efikasnija u upotrebi svoje imovine u generiranju budućih prihoda. Ove pokazatelje valja uzeti sa rezervom i uvijek kombinirati sa ostalim analitičkim metodama kako bismo dobili pravo tumačenje.

Za financijske kompanije nije moguće izračunati sve pokazatelje s obzirom na specifičnosti poslovanja i na drukčiju strukturu financijskih izvješća. To se prvenstveno odnosi na pokazatelje obrtaja imovine, i na tradicionalne pokazatelje likvidnosti i solventnosti. Kompanije iz financijskog sektora imaju posebne pokazatelje u ovoj kategoriji, ali s obzirom da HNB u svom Biltenu o bankama³ potvrđuje dobru kapitaliziranost banaka u Republici Hrvatskoj, nećemo posebno računati te pokazatelje kako bismo utvrdili stvarno stanje. Profitabilnost ćemo mjeriti kroz standardne pokazatelje EPS, ROE, ROA i Indeks financijske poluge. Svi pokazatelji efikasnosti investiranja dioničara se također lako mogu izračunati, pa ćemo ih računati i za financijska poduzeća.

Analiza financijskih izvješća je obavljena za 42 kompanije iz uzorka, te su računati gore spomenuti pokazatelji. Izvješća su preuzeta sa web stranica Zagrebačke burze i radi se o godišnjim izvješćima za 2010. godinu. Sva su izvješća revidirana i konsolidirana ako je poduzeće imalo obvezu konsolidacije, osim u slučaju Diokija i Validusa čija su izvješća za četvrti kvartal 2010., te nisu revidirana, kao i izvješća društva Kaštelanski staklenici d.d. čije je izvješće godišnje ali nije revidirano.

U Tablici 3 nalaze se izračunati financijski pokazatelji za sva poduzeća iz uzorka na temelju izvješća za 2010. godinu. Na temelju izračunatih pokazatelja iz

³ Hrvatska narodna banka: „Bilten o bankama“, prosinac 2010., str. 55.

početnog je uzorka eliminirano 14 kompanija. U Tablici 4 nalaze se eliminirane kompanije i razlozi eliminacije.

Iz tablice je očito da je najčešći uzrok eliminacije negativan financijski rezultat na koji se najčešće nadovezuju slaba likvidnost poduzeća i relativno visoka zaduženost. U nekoliko slučajeva razlog eliminacije je i trenutna precijenjenost dionice što je čini manje zanimljivim ulaganjem od alternativa.

Od deset definiranih sektora u njih 7 je eliminirana barem jedna kompanija. Najveće iznenađenje je sektor Hotelijerstvo i turizam u kojem su eliminirane sve 4 kompanije i taj sektor neće biti zastupljen u optimalnom portfelju. U 3 sektora nije eliminirana niti jedna kompanija, a to su: Energetika, Financije, te Prehrana i maloprodaja.

Nakon financijske analize i eliminacije nepoželjnih dionica, u uzorku ostaje 28 dionica koje će biti uključene u proces formiranja optimalnog portfelja pomoću Markowitzevog modela.

Tablica 3:

FINANCIJSKI POKAZATELJI PODUZEĆA IZ UZORKA ZA GODINU 2010.

Dionica	EPS (u kn)	ROE	ROA	Indeks fin. poluge	Koef. obrtaja DI	Koef. obrtaja KI	P/E	P/BV	BVPS	Koef. opće likvidnosti	Koef. ubrzanje likvidnosti	Koef. zaduže- nosti
ADPL-R-A	12,92	8,84%	5,32%	1,6601	1,05	2,08	10,65	0,8647	159,03 kn	1,1387	0,9438	36,14%
ADRS-P-A	28,39	7,19%	5,98%	1,2016	0,75	0,62	9,58	0,6424	423,38 kn	4,0821	3,4474	15,83%
ATGR-R-A	32,03	7,92%	2,14%	3,7031	0,73	1,25	22,79	1,6724	436,51 kn	1,2399	0,9168	71,47%
ATPL-R-A	27,70	2,73%	1,35%	2,0206	0,34	2,86	24,98	0,6634	1,043,09 kn	0,9561	0,9320	48,37%
BLJE-R-A	-7,70	-5,56%	-1,86%	2,9927	0,50	1,09	-11,69	0,6880	130,92 kn	1,8374	0,4376	67,68%
CKML-R-A	242,70	5,71%	4,28%	1,3347	2,67	2,91	16,07	0,8684	4,490,86 kn	2,2625	1,3112	22,83%
CROS-R-A	534,20	9,57%	1,91%	5,0020	-	-	10,76	0,9399	6,117,61 kn	-	-	-
DDJH-R-A	-15,87	-16,82%	-7,04%	2,3894	1,05	0,59	-2,39	0,4840	78,49 kn	2,4148	1,0821	60,50%
DIOK-R-A	-59,17	-60,63%	-10,65%	5,6932	1,30	3,93	-1,18	1,8217	38,42 kn	0,3635	0,2498	87,35%
DLKV-R-A	0,40	0,13%	0,04%	3,4342	1,71	1,04	567,82*	0,7395	306,95 kn	1,1710	0,8934	70,51%
ERNTR-R-A	18,07	2,30%	1,72%	1,3383	7,97	0,96	90,48	2,0329	804,28 kn	6,0849	5,8696	15,17%
FRNK-R-A	113,73	5,55%	3,88%	1,4329	1,77	0,85	7,06	0,3713	2,161,17 kn	2,7131	2,4235	29,04%
HDEL-R-A	2,78	0,90%	0,32%	2,8544	2,28	2,03	43,46	0,3882	311,67 kn	0,8932	0,6998	63,43%
HT-R-A	22,36	19,84%	15,57%	1,2741	1,05	1,53	11,67	1,9328	135,04 kn	3,1851	3,0591	12,94%
IGH-R-A	58,07	2,34%	0,69%	3,4065	0,70	0,92	27,54	0,6300	2,538,26 kn	0,9664	0,7110	69,45%
INA-R-A	95,50	8,07%	3,15%	2,5575	1,08	3,61	43,98	3,2830	1,279,30 kn	0,9270	0,5170	48,53%
INGR-R-A	-12,08	-15,39%	-5,03%	3,0578	0,20	0,47	-0,96	0,1744	66,41 kn	0,7305	0,2760	68,97%
ISTTR-R-A	-6,03	-3,84%	-2,18%	1,7594	0,31	9,46	-43,79	1,7503	150,83 kn	0,2979	0,2875	44,13%
JDPL-R-A	-28,92	-6,18%	-4,62%	1,3386	0,20	1,01	-4,84	0,3189	438,94 kn	1,0599	1,0390	22,94%
JNAF-R-A	143,28	3,45%	3,23%	1,0689	0,16	0,79	20,45	0,6826	4,292,70 kn	7,0080	6,9063	4,69%

Dionica	EPS (u kn)	ROE	ROA	Indeks fin. poluge	Koef. obrtaja DI	Koef. obrtaja KI	P/E	P/BV	BVPS	Koef. opće likvidnosti	Koef. ubrzane likvidnosti	Koef. zaduže- nosti
KNZM-R-A	18,18	23,79%	5,51%	4,3176	2,41	3,75	10,05	1,9320	94,62 kn	0,5464	0,2625	72,02%
KOEF-R-A	72,33	11,57%	5,98%	1,9340	2,08	1,17	8,07	0,8371	697,55 kn	2,7202	2,0935	26,02%
KORF-R-A	-13,04	-4,70%	-3,03%	1,5525	0,29	1,91	-5,52	0,2722	264,53 kn	1,2076	1,1724	35,32%
KRAS-R-A	14,17	3,09%	1,76%	1,7551	1,56	2,06	31,28	0,9389	472,16 kn	1,5172	1,0879	41,28%
KSST-R-A	-263,05	-9,00%	-7,15%	1,2590	0,03	2,33	-11,59	1,1462	2,661,00 kn	0,0818	0,0283	22,15%
LEDO-R-A	462,01	15,97%	10,83%	1,4753	2,37	1,77	12,45	1,7141	3,354,56 kn	3,0137	2,2744	28,93%
LKPC-R-A	70,24	8,11%	6,19%	1,3105	1,09	1,18	17,87	1,3410	935,87 kn	5,6789	5,5452	18,93%
LKRI-R-A	0,01	0,01%	0,01%	1,5053	0,44	2,73	33711,76*	3,1548	58,96 kn	0,7901	0,7673	27,85%
LRH-R-A	-159,28	-5,18%	-4,51%	1,1499	0,20	3,30	-12,05	0,6587	2,914,72 kn	1,5746	1,5398	10,38%
MAIS-R-A	-1,20	-1,42%	-0,67%	2,1310	0,27	9,37	-49,89	0,7197	83,36 kn	0,0520	0,0490	53,43%
PBZ-R-A	53,59	9,91%	1,39%	7,1167	-	-	10,37	0,9352	594,20 kn	-	-	-
PODR-R-A	15,51	5,42%	2,14%	2,5305	1,71	1,82	20,56	1,0576	301,63 kn	1,1493	0,7379	56,09%
PTKM-R-A	-40,74	-17,16%	-8,17%	2,1012	2,73	3,12	-4,00	0,8289	196,64 kn	0,8999	0,2962	55,89%
RIVP-R-A	-21,83	-5,92%	-3,32%	1,7823	0,27	7,35	-10,08	0,6338	347,10 kn	0,2864	0,2648	43,73%
THNK-R-A	61,85	3,75%	0,91%	4,1260	1,81	0,72	18,76	0,6772	1,712,96 kn	1,3528	0,9860	64,04%
TISK-R-A	5,69	3,29%	1,44%	2,2922	7,48	4,61	30,38	0,9685	178,59 kn	1,6075	1,3587	49,45%
TNPL-R-A	130,85	4,87%	2,41%	2,0175	0,37	1,43	10,24	0,4757	2,817,06 kn	1,5788	1,4728	47,62%
ULPL-R-A	166,64	18,44%	6,60%	2,7956	0,16	4,40	3,50	0,5447	1,070,36 kn	0,3713	0,3375	55,55%
VDKT-R-A	4,81	1,20%	0,29%	4,0807	1,32	3,58	47,85	0,5668	405,59 kn	0,5259	0,4361	67,75%
VIRO-R-A	18,21	4,22%	1,85%	2,2879	1,80	1,43	22,87	0,9271	449,23 kn	2,0119	1,0553	48,62%
VLD5-R-A	-10,53	-9,07%	-7,03%	1,2897	0,00	0,01	-1,20	0,1194	105,61 kn	0,9026	0,9026	64,93%
ZABA-R-A	22,07	9,68%	1,28%	7,5854	-	-	10,97	0,9684	249,91 kn	-	-	-
PROSJEK	43,07	1,12%	0,78%	2,5694	1,39	2,46	10,89	1,0087	1080,24 kn	1,7231	1,4018	44,88%

* Vrijednost nije korištena pri izračunu prosjeka jer se radi o ekstremnoj vrijednosti

Tablica 4:

KOMPANIJE KOJE SU ELIMINIRANE IZ POČETNOG UZORKA
I RAZLOZI ELIMINACIJE

Simbol	Razlog eliminacije
BLJE-R-A	Negativan financijski rezultat, slaba likvidnost, relativno visoka zaduženost
DDJH-R-A	Negativan financijski rezultat, slaba likvidnost, relativno visoka zaduženost
DIOK-R-A	Negativan financijski rezultat, precijenjenost dionice, slaba likvidnost, relativno visoka zaduženost
INGR-R-A	Negativan financijski rezultat, slaba likvidnost, relativno visoka zaduženost
ISTT-R-A	Negativan financijski rezultat, precijenjenost dionice, slaba likvidnost
JDPL-R-A	Negativan financijski rezultat
KORF-R-A	Negativan financijski rezultat
KSST-R-A	Negativan financijski rezultat, precijenjenost dionice, slaba likvidnost
LKRI-R-A	Precijenjenost dionice, slaba likvidnost
LRH-R-A	Negativan financijski rezultat
MAIS-R-A	Negativan financijski rezultat, slaba likvidnost, relativno visoka zaduženost
PTKM-R-A	Negativan financijski rezultat, slaba likvidnost, relativno visoka zaduženost
RIVP-R-A	Negativan financijski rezultat, slaba likvidnost
VLDS-R-A	Negativan financijski rezultat, relativno visoka zaduženost

3.4. Izračun varijabli za formiranje optimalnog portfelja

Markowitzeva se teorija portfelja zasniva na trima varijablama koje su ključne za formiranje optimalnog portfelja, a to su: očekivani prinos dionice $E(R)$, standardna devijacija (σ), te matrica varijanci i kovarijanci. Sve tri varijable se računaju na osnovi povijesnih promjena cijene dionica.

Povijesne promjene cijene se mogu računati na dnevnoj, tjednoj, mjesečnoj ili nekoj drugoj razini. Za ovaj rad je odabrana tjedna razina jer daje najbolju kombinaciju vremenskog obuhvata i dovoljan broj promatranja da bi rezultati bili signifikantni.

S obzirom da se od 21. ožujka 2011. indeks CROBEX računa s novim sastavnicama nakon redovite polugodišnje revizije indeksa⁴, a u uzorak su uključene

⁴ <http://zse.hr/default.aspx?id=34370>

i sve dionice sastavnice indeksa, tjedne cijene računamo za vrijeme od godinu dana prije tog datuma, tj. od 21. ožujka 2010., a baza podataka tjednih cijena je nadopunjena sve do 13. svibnja 2011. što znači da baza podataka sadrži ukupno 60 tjednih cijena. Tjedna cijena je aritmetička sredina dnevnih cijena u promatranom tjednu, a prilikom izračuna se pazilo na eventualne neradne dane tokom tjedna i dane kada se dionicom nije trgovalo. Tjedne promjene su izračunane na osnovi tjednih cijena po formuli:

$$R_x(t) = \ln \frac{P_x(t)}{P_x(t-1)} \quad (5)$$

gdje je $P_x(t)$ cijena dionice X u razdoblju t , a $P_x(t-1)$ cijena dionice X u razdoblju $t-1$. Tjedne promjene su računate samo za 28 dionica koje su se našle u suženom uzorku za formiranje optimalnog portfelja jer eliminirane dionice nemaju utjecaja na njegovo formiranje.

Kao što je već prije rečeno, očekivani tjedni prinos dionice $E(R_i)$ je prosjek tjednih promjena cijene i on se računa u tabličnom kalkulatoru Excel formulom AVERAGE(). Varijanca (σ^2) i standardna devijacija (σ) dionice se također računaju pomoću tjednih promjena cijene sa funkcijama VARP() i STDEV(). U sljedećoj tablici nalaze se očekivani prinosi, varijance i standardne devijacije 28 dionica u uzorku za formiranje optimalnog portfelja:

Tablica 5:

OČEKIVANI PRINOSI, VARIJANCE I STANDARDNE DEVIJACIJE DIONICA U UZORKU ZA FORMIRANJE OPTIMALNOG PORTFELJA

Dionica	E(R)	Varijanca	Stand. dev.	Dionica	E(R)	Varijanca	Stand. dev.
ADPL-R-A	0,6720%	0,00101279	3,1824%	KNZM-R-A	0,2392%	0,00118087	3,4364%
ADRS-P-A	-0,0933%	0,00057735	2,4028%	KOEI-R-A	0,2646%	0,00037759	1,9432%
ATGR-R-A	0,0971%	0,00016780	1,2954%	KRAS-R-A	0,2988%	0,00088240	2,9705%
ATPL-R-A	-0,5631%	0,00072323	2,6893%	LEDO-R-A	-0,0262%	0,00059126	2,4316%
CKML-R-A	0,3773%	0,00077024	2,7753%	LKPC-R-A	-0,4538%	0,00238617	4,8848%
CROS-R-A	0,1895%	0,00047417	2,1775%	PBZ-R-A	-0,0417%	0,00067594	2,5999%
DLKV-R-A	-0,5676%	0,00143681	3,7905%	PODR-R-A	-0,1501%	0,00081238	2,8502%
ERNT-R-A	-0,0423%	0,00082224	2,8675%	THNK-R-A	-0,4628%	0,00170831	4,1332%
FRNK-R-A	-0,1423%	0,00100310	3,1672%	TISK-R-A	-0,9079%	0,00237289	4,8712%
HDEL-R-A	-0,6088%	0,00217385	4,6625%	TNPL-R-A	-0,2063%	0,00069433	2,6350%
HT-R-A	-0,3911%	0,00067065	2,5897%	ULPL-R-A	-0,3282%	0,00049683	2,2290%
IGH-R-A	-0,6107%	0,00291205	5,3963%	VDKT-R-A	-0,4157%	0,00193618	4,4002%
INA-R-A	1,2155%	0,00465257	6,8210%	VIRO-R-A	0,2465%	0,00109936	3,3157%
INAF-R-A	-0,0297%	0,00074625	2,7318%	ZABA-R-A	-0,1367%	0,00076723	2,7699%

Tablica pokazuje neke vrlo zanimljive rezultate. Od 15 kompanija sa najboljim prinosom na kapital⁵ u 2010. godini, od kojih posljednja (FRNK-R-A) ima ROE od relativno visokih 5,55% (prosjeak je 1,12%), čak njih 8 ima negativan očekivani prinos u promatranom razdoblju. Iz toga možemo zaključiti da je hrvatsko tržište kapitala prilično neefikasno, jer iako je logično da su investitori imali smanjena očekivanja zbog svjetske recesije i teškog gospodarskog stanja u Republici Hrvatskoj, financijski rezultati većine najlikvidnijih poduzeća koja kotiraju na Zagrebačkoj burzi su ipak bili bolji od očekivanja, što se međutim nije odrazilo na cijene njihovih dionica. Iznimka je sektor Hotelijerstva i turizma u kojem sva poduzeća u uzorku imaju loše financijske rezultate u 2010. godini.

Druga je zanimljivost da je Građevina najrizičniji sektor, odnosno sektor sa najvećim cjenovnim oscilacijama. Svih pet građevinskih kompanija i samo 3 kompanije iz drugih sektora imaju tjednu standardnu devijaciju veću od 3,5%.

Najrizičnija kompanija u promatranom razdoblju je Ina d.d. (INA-R-A) s tjednom standardnom devijacijom od čak 6,82%, ali i najvećim očekivanim tjednim prinosom od 1,22%. Uzrok povišenom prinosu i riziku je znatno povećan promet i cijena nakon što je mađarski Mol d.d. objavio ponudu za preuzimanje⁶, a konzorcij mirovinskih fondova i Adrisa d.d.⁷ krenuo u kupnju dionica na Burzi kako bi spriječio Mađare da preuzmu većinski paket. U igru su se uključili i mnogi mali dioničari i špekulanti što je dovelo do značajnog povećanja i oscilacija cijene.

Najmanje rizična kompanija u promatranom razdoblju je Atlantic Grupa d.d. (ATGR-R-A) koja je imala tjednu standardnu devijaciju od samo 1,30% i tjedni očekivani prinos od 0,0971%.

Matrica varijanci i kovarijanci je izrađena u dva koraka. Prvo je izrađena tablica razlika pojedinih tjednih prinosa i očekivanog prinosa (R-E(R) tablica)⁸ za svih 28 dionica iz uzorka, a u drugom koraku je pomoću Excelovih funkcija MMULT() i TRANSPOSE() formirana matrica varijanci i kovarijanci. Cjelovita formula za izradu matrice izgleda ovako:

$$= \frac{MMULT(TRANSPOSE(vrijednosti\ tablice\ R - E(R));\ vrijednosti\ tablice\ R - E(R))}{60}$$

⁵ vidi Tablicu 3

⁶ <http://www.poslovnih.hr/vijesti/mol-objavio-opcu-ponudu-za-preuzimanje-dionica-ine-166465.aspx>

⁷ <http://www.poslovnih.hr/vijesti/mirovinci-ce-kupovati-dionice-ine-adris-spreman-na-suradnju-s-vladom-166109.aspx>

⁸ Detaljnije o izračunu matrice varijanci i kovarijanci vidjeti u Aljinović, Marasović, Šego (2011), str.134-136

U ovom slučaju se radi o Excelovoj tzv. *array* funkciji koja računa pojedinačne vrijednosti za sve ćelije. Vrijednost dobivena Excelovim funkcijama se dijeli sa 60 jer je 60 tjednih promjena u izračunu.

Većina dionica, što je bilo i očekivano, međusobno pozitivno kovarira. Od 28 dionica, 13 ih ima barem jednu negativnu kovarijancu, a samo četiri imaju 3 ili više negativnih kovarijanci. To su ATGR-R-A, CROS-R-A, HT-R-A i KRAS-R-A. ATGR-R-A i KRAS-R-A koje imaju po 3 negativne kovarijance, a CROS-R-A i HT-R-A po 4 negativne kovarijance. Te informacije nisu dovoljne da bi se mogli izvući nekakvi posebni zaključci, jer se radi o negativnom kovariranju više različitih dionica iz više sektora i nema prepoznatljivog obrasca i ponavljanja. Kada bi se neka dionica ili sektor isticao po broju kovarijanci onda bismo mogli reći da je to neka vrsta „utočišta“ investitorima, te da kada cijene padaju investitori kapital prebacuju u tu dionicu (sektor) i ona raste, što je uzrok pojave negativnih kovarijanci. Mi ovdje nemamo nijedan takav ekstremni slučaj.

Kada su sve tri bitne varijable – očekivani prinos, standardna devijacija, te matrica varijanci i kovarijanci izračunane, može se pristupiti formiranju optimalnog portfelja.

3.5. Postavljanje ograničenja i formiranje portfelja

Optimalni portfelj smo formirali iz uzorka od 28 dionica koje su se, nakon analize financijskih pokazatelja, pokazale potencijalno zanimljivim ulaganjima. Koristili smo se tabličnim kalkulatorom Excel i njegovim alatom Solver. Ranije izračunani očekivani prinosi, standardne devijacije, i matrica varijanci i kovarijanci su bili osnovni izvori podataka potrebni za formiranje portfelja.

Portfelj je formiran na temelju sljedećih pretpostavki:

- traženi godišnji prinos je 12%, a cilj je smanjiti rizik (standardnu devijaciju),
- ne smijemo biti izloženi nijednoj pojedinoj dionici više od 15%,
- ne smijemo biti izloženi nijednom pojedinom sektoru više od 35%,
- u svrhu diverzifikacije, svaki sektor mora biti zastupljen sa minimalno 5% udjela (osim sektora turizma koji nema predstavnika).

Sukladno tome su formulirana ograničenja koja se mogu vidjeti unutar prozora alata Solver na slici 2. Program je zatim iterativnom metodom mijenjao i kombinirao udjele dionica, kako bi ispunio postavljene ciljeve pritom poštujući zadana ograničenja.

Slika 2:

PRIKAZ SUČELJA U EXCELU NAKON ŠTO SU UNESENA OGRAIČENJA I IZVRŠEN IZRAČUN

	A	B	C	D	E	F	G	H	I
1	DIONICA	UDIO	E(R)	σ	Sektor			Tjedni	Godišnji
2	ADPL-R-A	12,6072%	0,6720%	3,1824%	Industrija	E(R) portfelja		0,22%	12,00%
3	ADRS-P-A	5,0000%	-0,0933%	2,4028%	Diverzificirano	σ portfelja		1,34%	9,63%
4	ATGR-R-A	15,0000%	0,0971%	1,2954%	Prehrana i maloprodaja				
5	ATPL-R-A	0,0000%	-0,5631%	2,6893%	Transport	Zbroj udjela - portfelj		100,00%	
6	CKML-R-A	12,2657%	0,3773%	2,7753%	Poljoprivreda	Zbroj udjela - sektori		100,00%	
7	CROS-R-A	15,0000%	0,1895%	2,1775%	Financije	Broj dionica u portfelju		13	
8	DLKV-R-A	0,0000%	-0,5676%	3,7905%	Građevina				
9	ERNT-R-A	0,0000%	-0,0423%	2,8675%	Telekomunikacije	Sektori	Udio sektora	E(R) sektora	
10	FRNK-R-A	0,0000%	-0,1423%	3,1672%	Prehrana i maloprodaja	Diverzificirano	5,0000%	-0,0047%	
11	HDEL-R-A	1,2208%	-0,6088%	4,6625%	Građevina	Energetika	5,0000%	0,0443%	
12	HT-R-A	5,0000%	-0,3911%	2,5897%	Telekomunikacije	Financije	15,0000%	0,0284%	
13	IGH-R-A	0,0000%	-0,6107%	5,3963%	Građevina	Građevina	5,0000%	-0,0231%	
14	INA-R-A	3,6785%	1,2155%	6,8210%	Energetika	Industrija	20,1491%	0,1047%	
15	JNAF-R-A	1,3215%	-0,0297%	2,7318%	Energetika	Poljoprivreda	12,2657%	0,0463%	
16	KNZM-R-A	0,0000%	0,2392%	3,4364%	Prehrana i maloprodaja	Prehrana i maloprodaja	27,5852%	0,0522%	
17	KOEI-R-A	7,5419%	0,2646%	1,9432%	Industrija	Telekomunikacije	5,0000%	-0,0196%	
18	KRAS-R-A	12,5852%	0,2988%	2,9705%	Prehrana i maloprodaja	Transport	5,0000%	-0,0103%	
19	LEDO-R-A	0,0000%	-0,0262%	2,4316%	Prehrana i maloprodaja	Hoteljerstvo i turizam	0,0000%	0,0000%	
20	LKPC-R-A	0,0000%	-0,4538%	4,8848%	Transport				
21	PBZ-R-A	0,0000%	-0,0417%	2,5999%	Financije	<div> <div>Solver Parameters</div> <div> Set Target Cell: <input type="text" value="\$I\$3"/> <input type="button" value="FV"/> <input type="button" value="Solve"/> <input type="button" value="Close"/> </div> <div> Equal To: <input type="radio"/> Max <input checked="" type="radio"/> Min <input type="radio"/> Value of: <input type="text" value="0"/> </div> <div> By Changing Cells: <input type="text" value="\$B\$2:\$B\$29"/> <input type="button" value="Guess"/> </div> <div> Subject to the Constraints: <div> <div>\$B\$2:\$B\$29 <= 0,15</div> <div>\$H\$10:\$H\$18 <= 0,35</div> <div>\$H\$10:\$H\$18 >= 0,05</div> <div>\$H\$5 = 1</div> <div>\$I\$2 >= 0,12</div> </div> <div> <input type="button" value="Add"/> <input type="button" value="Change"/> <input type="button" value="Delete"/> </div> </div> <div> <input type="button" value="Options"/> <input type="button" value="Reset All"/> <input type="button" value="Help"/> </div> </div>			
22	PODR-R-A	0,0000%	-0,1501%	2,8502%	Preh				
23	THNK-R-A	0,0000%	-0,4628%	4,1332%	Građ				
24	TISK-R-A	0,0000%	-0,9079%	4,8712%	Preh				
25	TNPL-R-A	5,0000%	-0,2063%	2,6350%	Tran				
26	ULPL-R-A	0,0000%	-0,3282%	2,2290%	Tran				
27	VDKT-R-A	3,7792%	-0,4157%	4,4002%	Građ				
28	VIRO-R-A	0,0000%	0,2465%	3,3157%	Polj				
29	ZABA-R-A	0,0000%	-0,1367%	2,7699%	Fina				
30									
31									
32									
33									

Uočimo da se do optimalnog portfelja došlo minimiziranjem rizika uz postavljeni željeni tjedni prinos od 0.22%, uz standardna ograničenja (3) i (4), čemu su dodana navedena ograničenja izloženosti pojedinoj dionici i zastupljenosti pojedinog sektora.

Optimalni portfelj se sastoji od sljedećih dionica s njihovim pripadajućim udjelima:

Tablica 6:

DIONIČKA STRUKTURA OPTIMALNOG PORTFELJA

Dionica	Udio	E(R)	Stand. dev.	Sektor
ADPL-R-A	12,6072%	0,6720%	3,1824%	Industrija
ADRS-P-A	5,0000%	-0,0933%	2,4028%	Diverzificirano
ATGR-R-A	15,0000%	0,0971%	1,2954%	Prehrana i maloprodaja
CKML-R-A	12,2657%	0,3773%	2,7753%	Poljoprivreda
CROS-R-A	15,0000%	0,1895%	2,1775%	Financije
HDEL-R-A	1,2208%	-0,6088%	4,6625%	Građevina
HT-R-A	5,0000%	-0,3911%	2,5897%	Telekomunikacije
INA-R-A	3,6785%	1,2155%	6,8210%	Energetika
JNAF-R-A	1,3215%	-0,0297%	2,7318%	Energetika
KOEI-R-A	7,5419%	0,2646%	1,9432%	Industrija
KRAS-R-A	12,5852%	0,2988%	2,9705%	Prehrana i maloprodaja
TNPL-R-A	5,0000%	-0,2063%	2,6350%	Transport
VDKT-R-A	3,7792%	-0,4157%	4,4002%	Građevina

Optimalni portfelj sadrži 13 dionica, ima ciljani godišnji prinos od 12% i standardnu devijaciju od 9,63%. Pet dionica ima udjele veće od 10%, a najveći su udjeli Atlantic Grupe d.d. i Croatia osiguranja d.d. U portfelju postoji čak 6 dionica s negativnim očekivanim prinosom, međutim one zajedno imaju tek 21,32% udjela i uvrštene su u portfelj radi zadovoljavanja uvjeta sektorske diverzifikacije.

Ovdje se radi o jednom konzervativnom, umjereno rizičnom portfelju, koji pritom ipak ima vrlo solidan očekivani prinos. Usporedbe radi, burzovni je indeks CROBEX u posljednjih godinu dana porastao tek 6,17%, što je upola manje od očekivanog prinosa ovog portfelja. Njegovu kvalitetu, ali i konzervativnost potvrđuje i činjenica da sadrži čak 5 dionica koje se smatraju *blue chip* dionicama na hrvatskom tržištu kapitala, a to su ADRS-P-A, ATGR-R-A, HT-R-A, INA-R-A i KOEI-R-A. Od 15 dionica koje su imale najbolji ROE u 2010. godini čak 8 ih se nalazi u ovom portfelju. Nijedna kompanija osim Viadukta d.d. nema problema s likvidnošću, međutim Viadukt d.d. ima solidan financijski rezultat i iznadprosječne pokazatelje efikasnosti, što pokazuje da će vjerojatno biti u mogućnosti podmiriti sve svoje obveze kada naplati potraživanja. Samo 3 kompanije imaju povišenu zaduženost, ali s obzirom na njihove financijske rezultate to ne bi morao biti problem u budućnosti.

Što se tiče sektorske strukture portfelja, možemo primijetiti nekoliko vrlo zanimljivih trendova. Najveći udio ima sektor Prehrana i maloprodaja od 27,58%,

zatim slijede Industrija sa 20,15% i Financije sa 15%. Sektor Prehrana i maloprodaja je formiran po uzoru na sektor necikličkih potrošačkih dobara u GICS klasifikaciji i on je obično vrlo stabilan bez velikih cjenovnih oscilacija. To dokazuju i rezultati kompanija u tom sektoru, ali i njihov vrlo nizak rizik. Stoga ne čudi da taj sektor ima glavnu ulogu u portfelju kojemu je cilj stabilan prihod uz minimiziran rizik.

Slično se može reći i za sektor Industrija, međutim ovaj sektor nikako nije reprezentant čitave hrvatske industrije, koja je u gospodarskoj krizi, nego je on predstavljen kroz dvije vrlo kvalitetne dionice – ADPL-R-A i KOEI-R-A. Solinski AD Plastik d.d. se u posljednjih nekoliko godina pokazao kao kompanija s vrlo svijetlom budućnosti, s obzirom na izvrsne financijske rezultate, dobru likvidnost i efikasnost i još uvijek jako nisku zaduženost. Končar d.d. se smatra *blue chip* dionicom i ima obilježja nisko volatilne kompanije, koja uobičajeno ima vrlo dobre rezultate. Bitno obilježje obiju kompanija je da su jako izvezno orijentirane i da imaju dobru reputaciju na stranim tržištima.

Treći najveći sektor u portfelju su Financije. Radi se o sektoru koji tradicionalno ima stabilne i relativno visoke prinose i nisku volatilnost dionica. Hrvatski financijski sektor je obično vrlo siguran i dobro kapitaliziran, što je rezultat čvrste regulacije HNB-a. Taj sektor zastupa Croatia osiguranje d.d. koju odlikuje relativno niska volatilnost i stabilan prinos. Ostale dionice iz tog sektora su imale negativan očekivani prinos unatoč dobrim rezultatima, što može biti signal da su podbacile u odnosu na očekivanja investitora.

Tablica 7:

SEKTORSKA STRUKTURA OPTIMALNOG PORTFELJA

Sektor	Udio sektora	E(R) sektora
Diverzificirano	5,0000%	-0,0047%
Energetika	5,0000%	0,0443%
Financije	15,0000%	0,0284%
Građevina	5,0000%	-0,0231%
Hoteljerstvo i turizam	0,0000%	0,0000%
Industrija	20,1491%	0,1047%
Poljoprivreda	12,2657%	0,0463%
Prehrana i maloprodaja	27,5852%	0,0522%
Telekomunikacije	5,0000%	-0,0196%
Transport	5,0000%	-0,0103%

Treba spomenuti i sektor Poljoprivreda koji ima udio od 12,27% i u potpunosti ga predstavljaju Čakovečki mlinovi d.d. koji također imaju vrlo dobru kombinaciju rizika i prinosa. Ostali sektori zauzimaju minimalnih 5%, i svi osim Energetike imaju negativne prinose. Sektor Energetika, predstavljen kroz Inu d.d. i Janaf d.d. generalno ima vrlo dobar prinos, ali i jako visok rizik (prvenstveno Ina), stoga je njegov udio smanjen na optimalnu razinu. Kao što je i prije spomenuto, sektor Hotelijerstvo i turizam nema nijednog predstavnika ni udio u portfelju s obzirom da su sve 4 njegove dionice iz početnog uzorka eliminirane kroz analizu financijskih pokazatelja.

Zaključno možemo reći da se radi o jednom konzervativnom i stabilnom portfelju, koji ima relativno nizak rizik i vrlo dobar očekivani prinos. Prisutnost čak 5 *blue chip* dionica, kao i nekih kompanija s vrlo brzim rastom (ADPL-R-A i CROS-R-A) pokazuje da je ostvarenje godišnjeg prinosa od 12% vrlo realna mogućnost. Svi su bitni sektori zastupljeni, a onima sa stabilnijim prinosima i nižim rizikom je dan veći udio. Istovremeno je ispunjen i minimalni zahtjev sektorske diverzifikacije.

Ovaj portfelj je pogodan za sve investitore koji nisu skloni riziku, ali ipak žele ostvariti solidne prinose na godišnjoj razini.

4. Zaključak

Primjenjujući Markowitzev model pokazano je da se na hrvatskom tržištu kapitala može uspješno formirati optimalan dionički portfelj, koji će zadovoljavati sve postavljene uvjete i ograničenja. Pokazano je da je moguće postići čak i bolji prinos u odnosu na tržišni indeks CROBEX (12% u odnosu na 6,17%) bez preuzimanja značajnog rizika, uz standardnu devijaciju od 9,63%.

Vrlo važan aspekt pri formiranju portfelja je bila i analiza financijskih pokazatelja, koja je pokazala da neke dionice iako imaju pozitivan očekivani prinos, također imaju vrlo loše financijske rezultate i kao takve su nepoželjne u portfeljima investitora koji nisu skloni riziku i špekuliranju. Za postizanje dobrih investicijskih rezultata bitno je kombinirati statističke metode sa financijskim i računovodstvenim metodama, kako bi se potencijalna investicija sagledala sa svih strana i kako bi se mogla donijeti kvalitetna investicijska odluka.

Pokazano je i da nije dovoljno portfelj samo dionički diverzificirati, nego da treba uzeti u obzir i sektorsku pripadnost, s obzirom da u nekim slučajevima cijeli sektori imaju jako loše (Građevina, Hotelijerstvo i turizam) ili jako dobre rezultate (Industrija, Prehrana i maloprodaja). Sektorska diverzifikacija je bitna kako bi se smanjio utjecaj cikličkih oscilacija gospodarstva na naš portfelj, ali i maksimizirali prinosi od uzleta pojedinih sektora.

Konačni portfelj bi spadao u skupinu konzervativnih i stabilnih portfelja, jer ostvaruje vrlo solidan prinos od 12% uz relativno nisku stopu rizika. Sadrži dionice koje se smatraju *blue chip* dionicama na hrvatskom tržištu kapitala i ima dobru sektorsku i dioničku diverzifikaciju. Pogodan je za sve investitore koji nisu skloni riziku, ali ipak žele ostvariti solidne prinose na godišnjoj razini.

Buduća istraživanja na ovu temu bi trebala pomaknuti fokus sa samo dionica na sve financijske instrumente i vrijednosne papire u koje je moguće investirati na hrvatskom tržištu kapitala. Tu spadaju obveznice, štedni depoziti, instrumenti tržišta novca, udjeli u investicijskim fondovima, a u budućnosti i derivativi i valute. Takvo proširenje fokusa i investicijskih prilika će omogućiti formiranje još raznolikijih portfelja koji će moći zadovoljiti različite preferencije investitora.

LITERATURA

- Aljinović, Z., Marasović, B., Šego, B. (2011). *Financijsko modeliranje*, 2. izmijenjeno i dopunjeno izdanje. Split: Ekonomski fakultet u Splitu.
- Aljinović, Zdravka – Materijali za kolegij Financijsko modeliranje
- Belak, V. (1995). *Menadžersko računovodstvo*. Zagreb: RRIF.
- Brealey, R., Myers, S. (2003). *Principles of Corporate Finance*, 7th Ed. New York: McGraw-Hill/Irwin
- Garrison, R., Noreen, E. (2000). *Managerial Accounting*, 9th Ed. McGraw-Hill/Irwin, International Edition.
- Vidučić, L.J. (2002). *Financijski management*. Zagreb: RRIF.
- www.hnb.hr – Web stranica Hrvatske narodne banke, adekvatnost kapitala banaka
- www.mscibarra.com/products/indices/gics - Sektorska klasifikacija, GICS standard
- www.zse.hr – Web stranica Zagrebačke burze.

FORMING THE OPTIMAL PORTFOLIO BASED ON THE MARKOWITZ MODEL WITH DIVERSIFICATION OF COMPANIES BY SECTORS

Summary

The Markowitz' (mean-variance, MV) model is applied in forming the optimal portfolio based on a sample of stocks quoted on The Zagreb Stock Exchange, considering

defined and adjusted constraints, where special attention is given to the portfolio diversification not only by stock, but also by sector. Also, very important aspect is the analysis of financial indicators which shows that some stocks, although with positive expected return, have very bad financial results and consequently they are not advisable in portfolios of risk and speculation averse investors. All calculations are presented and carried out by table calculator Excel where Solver is used for solving mathematical programming i.e. optimization problem. The result of such comprehensive analysis and optimization process is a portfolio in the group of conservative and stable portfolios, with very solid annual return of 12% and relatively low risk. It consists of stocks considered as *blue chip* stocks on the Croatian stock market and has very good sector and stock diversification. It is suitable for investors who are risk averse, but also want to reach solid annual returns.

Key words: Markowitz' portfolio optimization model, The Zagreb Stock Exchange, allocation by sector, the analysis of financial reports, Excel